PATENT ABSTRACTS OF JAPAN

(11)Publication number:

2002-162986

(43) Date of publication of application: 07.06.2002

(51)Int.Cl.

G10L 13/08

G10L 13/00

G10L 15/06

G10L 13/04

(21)Application number: 2000-360207

(71)Applicant: CANON INC

(22)Date of filing:


27.11.2000

(72)Inventor: AIZAWA MICHIO

(54) DEVICE AND METHOD FOR INFORMATION PROCESSING AND COMPUTER-READABLE MEMORY

(57)Abstract:

PROBLEM TO BE SOLVED: To provide a device and a method for information processing and a computer-readable memory which can generate a highly flexible and precise dictionary for voice synthesis. SOLUTION: An initial setting hold part 101 specifies the number of words constituting a small-size dictionary 112. A small-size dictionary hold part 107 constitutes the small-size dictionary 112 according to learning document data 109 for determining the words constituting the small-size dictionary 112 and large-amount document data 108. An accent processing part 103 performs accent processing for evaluation document data 110 for evaluating the small-size dictionary 112 by using a system dictionary 111 to output 1st accent phrase information and performs accent processing by using the small-size dictionary to output 2nd accent phrase information. An accent phrase relative precision evaluation part 106 calculates the relative precision of the 2nd accent phrase information to the 1st accent phrase information. Then the small-size dictionary hold part 107 performs management while making the relative precision and small-size dictionary 112 correspond to each other.



LEGAL STATUS

[Date of request for examination]

10.06.2004

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

			•

(19) 日本国特許庁 (JP)

(12)公開特許公報 (A)

(11)特許出願公開番号 特開2002—162986

(P2002-162986A) (43)公開日 平成14年6月7日(2002.6.7)


(51) Int. Cl. 7	識別記号	F I -		
G10L 13/08	•	G10L 3/00 H 5D015		
13/00		Q 5D045		
15/06		521 C		
13/04		521 F		
		5/02 G		
		審査請求 未請求 請求項の数11 〇L (全8頁)		
(21)出願番号	特願2000-360207(P2000-360207)	(71)出願人 000001007		
		キヤノン株式会社		
(22)出願日	平成12年11月27日(2000.11.27)	東京都大田区下丸子3丁目30番2号		
	·	(72)発明者 相澤 道雄		
		東京都大田区下丸子3丁目30番2号 キヤ		
		ノン株式会社内		
		(74)代理人 100076428		
	·	弁理士 大塚 康徳 (外2名)		
		Fターム(参考) 5D015 GG01		
		5D045 AA09 AB01		
		· ·		

(54) 【発明の名称】情報処理装置及びその方法、コンピュータ可読メモリ

(57)【要約】

【課題】 汎用性が高く、かつ精度の良い音声合成用辞書を作成することができる情報処理装置及びその方法、コンピュータ可読メモリを提供する。

【解決手段】 初期設定保持部101で、小型辞書112を構成する単語数を指定する。次に、小型辞書保持部107で、小型辞書112を構成する単語を決定するための学習用文書データ109と、大量文章データ108に基づいて、該小型辞書112を構成する。アクセント処理部103は、小型辞書112を評価するための評価用文章データ110に対し、システム辞書111を用いてアクセント処理を行ない、第1アクセント句情報を出力し、また、評価用文章データ110に対し、小型辞書112を用いてアクセント処理を行い、第2アクセント句情報を出力する。そして、アクセント句相対精度評価部106は、第2アクセント句情報の第1アクセント句情報に対する相対精度を算出する。そして、小型辞書保持部107は、相対精度と小型辞書112を対応づけて管理する。



1

【特許請求の範囲】

【請求項1】 予め登録されているシステム辞書に基づいて分野毎の小型辞書を作成する情報処理装置であって、

前記小型辞書を構成する単語数を指定する指定手段と、 前記小型辞書を構成する単語を決定するための学習用文 書データと、大量文章データに基づいて、該小型辞書を 構成する構成手段と、

前記小型辞書を評価するための評価用文章データに対し、前記システム辞書を用いてアクセント処理を行ない、第1アクセント句情報を出力する第1アクセント処理手段と、

前記評価用文章データに対し、前記小型辞書を用いてアクセント処理を行い、第2アクセント句情報を出力する第2アクセント処理手段と、

前記第2アクセント句情報の前記第1アクセント句情報 に対する相対精度を算出する算出手段と、

前記相対精度と前記小型辞書を対応づけて管理する管理 手段とを備えることを特徴とする情報処理装置。

【請求項2】 前記指定手段は、前記小型辞書を構成す 20 る全単語数と、該全単語数の内、前記学習用文書データ から得られる単語から選ぶ単語数との組を指定すること を特徴とする請求項1に記載の情報処理装置。

【請求項3】 前記構成手段は、前記学習用文書データ 及び前記大量文書データそれぞれに対し形態素解析を行 う形態素解析手段とを備え、

前記形態素解析手段の形態素解析結果に基づいて、前記 小型辞書を構成することを特徴とする請求項1に記載の 情報処理装置。

【請求項4】 前記相対精度は、前記第2アクセント情 30 報が前記第1アクセント情報と一致する度合を示すこと を特徴とする請求項1に記載の情報処理装置。

【請求項5】 前記学習用文章データ及び前記評価用文章データは、分野毎に存在することを特徴とする請求項1に記載の情報処理装置。

【請求項6】 予め登録されているシステム辞書に基づいて分野毎の小型辞書を作成する情報処理方法であって、

前記小型辞書を構成する単語数を指定する指定工程と、 前記小型辞書を構成する単語を決定するための学習用文 40 書データと、大量文章データに基づいて、該小型辞書を 構成する構成工程と、

前記小型辞書を評価するための評価用文章データに対し、前記システム辞書を用いてアクセント処理を行ない、第1アクセント句情報を出力する第1アクセント処理工程と、

前記評価用文章データに対し、前記小型辞書を用いてアクセント処理を行い、第2アクセント句情報を出力する第2アクセント処理工程と、

前記第2アクセント句情報の前記第1アクセント句情報 50

に対する相対精度を算出する算出工程と、

前記相対精度と前記小型辞書を対応づけて記憶媒体に管理する管理工程とを備えることを特徴とする情報処理方法。

【請求項7】 前記指定工程は、前記小型辞書を構成する全単語数と、該全単語数の内、前記学習用文書データから得られる単語から選ぶ単語数との組を指定することを特徴とする請求項6に記載の情報処理方法。

【請求項8】 前記構成工程は、前記学習用文書データ 10 及び前記大量文書データそれぞれに対し形態素解析を行 う形態素解析工程とを備え、

前記形態素解析工程の形態素解析結果に基づいて、前記 小型辞書を構成することを特徴とする請求項6に記載の 情報処理方法。

【請求項9】 前記相対精度は、前記第2アクセント句情報が前記第1アクセント情報と一致する度合を示すことを特徴とする請求項6に記載の情報処理方法。

【請求項10】 前記学習用文章データ及び前記評価用 文章データは、分野毎に存在することを特徴とする請求 項6に記載の情報処理方法。

【請求項11】 予め登録されているシステム辞書に基づいて分野毎の小型辞書を作成する情報処理のプログラムコードが格納されたコンピュータ可読メモリであって、

前記小型辞書を構成する単語数を指定する指定工程のプログラムコードと、

前記小型辞書を構成する単語を決定するための学習用文 書データと、大量文章データに基づいて、該小型辞書を 構成する構成工程のプログラムコードと、

前記小型辞書を評価するための評価用文章データに対し、前記システム辞書を用いてアクセント処理を行ない、第1アクセント句情報を出力する第1アクセント処理工程のプログラムコードと、

前記評価用文章データに対し、前記小型辞書を用いてアクセント処理を行い、第2アクセント句情報を出力する第2アクセント処理工程のプログラムコードと、

前記第2アクセント句情報の前記第1アクセント句情報 に対する相対精度を算出する算出工程のプログラムコー ドと、

前記相対精度と前記小型辞書を対応づけて記憶媒体に管理する管理工程とを備えることを特徴とするコンピュータ可読メモリ。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】本発明は、予め登録されているシステム辞書に基づいて分野毎の小型辞書を作成する情報処理装置及びその方法、コンピュータ可読メモリに関するものである。

[0002]

【従来の技術】音声合成システムや音声認識システム等

では、音声認識用としてシステムの持つ数十万語レベルのシステム辞書から数千語~数万語の単語を取り出したサブセットの小型辞書がよく使われる。これは、実行速度の向上やメモリサイズの削減を目的としている。

【0003】例えば、コンピュータ関係の文書と経済関係の文章では、異なる単語が出現する。しかし、小型辞書では、語数を制限しているため様々な分野の単語(特に、専門用語等)を同時に収録することができない。そのため、コンピュータ関係、経済関係等の適用分野に合わせて小型辞書に登録する選択単語を変化させる必要が 10ある。

【0004】適用分野に応じて、小型辞書に登録する単語を選択する最も簡単な方法は、その適用分野の大量の文章から単語の出現頻度を計算し、出現頻度の上位から設定した語数までの単語を選ぶ方法がある。しかし、一般に適用分野に応じた文章を大量に集めることは困難である。そこで、新聞記事等の大量に入手できる文章と適用分野の少量の文章に基づいて、小型辞書に登録する単語を選択する方法を行っている。

【0005】例えば、特開2000-75892号では、大量にある過去のニュース原稿と、少量の最近のニュース原稿から、小型辞書に登録する単語を選択している。

[0006]

【発明が解決しようとする課題】しかしながら、従来の特開 2000-75892号で開示される方法は、単語選択の評価基準としてパープレキシティを用いている。パープレキシティはnグラムモデルを用いた統計的手法に関係する値である。そのため、統計的手法を用いていないシステムにおいては有効性が低い。

[0007] 本発明は上記の課題を解決するためになされたものであり、汎用性が高く、かつ精度の良い音声合成用辞書を作成することができる情報処理装置及びその方法、コンピュータ可読メモリを提供することを目的とする。

〔発明の詳細な説明〕

【発明の属する技術分野】本発明は、予め登録されているシステム辞書に基づいて分野毎の小型辞書を作成する情報処理装置及びその方法、コンピュータ可読メモリに関するものである。

[0008]

【従来の技術】音声合成システムや音声認識システム等では、音声認識用としてシステムの持つ数十万語レベルのシステム辞書から数千語~数万語の単語を取り出したサブセットの小型辞書がよく使われる。これは、実行速度の向上やメモリサイズの削減を目的としている。

[0009] 例えば、コンピュータ関係の文書と経済関係の文章では、異なる単語が出現する。しかし、小型辞書では、語数を制限しているため様々な分野の単語(特に、専門用語等)を同時に収録することができない。そ 50

のため、コンピュータ関係、経済関係等の適用分野に合わせて小型辞書に登録する選択単語を変化させる必要がある。

[0010] 適用分野に応じて、小型辞書に登録する単語を選択する最も簡単な方法は、その適用分野の大量の文章から単語の出現頻度を計算し、出現頻度の上位から設定した語数までの単語を選ぶ方法がある。しかし、一般に適用分野に応じた文章を大量に集めることは困難である。そこで、新聞記事等の大量に入手できる文章と適用分野の少量の文章に基づいて、小型辞書に登録する単語を選択する方法を行っている。

【0011】例えば、特開2000-75892号では、大量にある過去のニュース原稿と、少量の最近のニュース原稿から、小型辞書に登録する単語を選択している。

[0012]

【発明が解決しようとする課題】しかしながら、従来の特開2000-75892号で開示される方法は、単語選択の評価基準としてパープレキシティを用いている。 20 パープレキシティはnグラムモデルを用いた統計的手法に関係する値である。そのため、統計的手法を用いていないシステムにおいては有効性が低い。

【0013】本発明は上記の課題を解決するためになされたものであり、汎用性が高く、かつ精度の良い音声合成用辞書を作成することができる情報処理装置及びその方法、コンピュータ可読メモリを提供することを目的とする。

[0014]

組を指定する。

【課題を解決するための手段】上記の目的を達成するた めの本発明による情報処理装置は以下の構成を備える。 即ち、予め登録されているシステム辞書に基づいて分野 毎の小型辞書を作成する情報処理装置であって、前記小 型辞書を構成する単語数を指定する指定手段と、前記小 型辞書を構成する単語を決定するための学習用文書デー タと、大量文章データに基づいて、該小型辞書を構成す る構成手段と、前記小型辞書を評価するための評価用文 章データに対し、前記システム辞書を用いてアクセント **処理を行ない、第1アクセント句情報を出力する第1ア** クセント処理手段と、前記評価用文章データに対し、前 記小型辞書を用いてアクセント処理を行い、第2アクセ 40 ント句情報を出力する第2アクセント処理手段と、前記 第2アクセント句情報の前記第1アクセント句情報に対 する相対精度を算出する算出手段と、前記相対精度と前 記小型辞書を対応づけて管理する管理手段とを備える。 【0015】また、好ましくは、前記指定手段は、前記 小型辞書を構成する全単語数と、該全単語数の内、前記 学習用文書データから得られる単語から選ぶ単語数との

【0016】また、好ましくは、前記構成手段は、前記 学習用文書データ及び前記大量文書データそれぞれに対 し形態素解析を行う形態素解析手段とを備え、前記形態 素解析手段の形態素解析結果に基づいて、前記小型辞書 を構成する。

【0017】また、好ましくは、前記相対精度は、前記 第2アクセント句情報が前記第1アクセント情報と一致 する度合を示す。

[0018] また、好ましくは、前記学習用文章データ 及び前記評価用文章データは、分野毎に存在する。

【0019】上記の目的を達成するための本発明による 情報処理方法は以下の構成を備える。即ち、予め登録さ 10 れているシステム辞書に基づいて分野毎の小型辞書を作 成する情報処理方法であって、前記小型辞書を構成する 単語数を指定する指定工程と、前記小型辞書を構成する 単語を決定するための学習用文書データと、大量文章デ ータに基づいて、該小型辞書を構成する構成工程と、前 記小型辞書を評価するための評価用文章データに対し、 前記システム辞書を用いてアクセント処理を行ない、第 1アクセント句情報を出力する第1アクセント処理工程 と、前記評価用文章データに対し、前記小型辞書を用い てアクセント処理を行い、第2アクセント句情報を出力 20 する第2アクセント処理工程と、前記第2アクセント句 情報の前記第1アクセント句情報に対する相対精度を算 出する算出工程と、前記相対精度と前記小型辞書を対応 づけて記憶媒体に管理する管理工程とを備える。

【0020】上記の目的を達成するための本発明による コンピュータ可読メモリは以下の構成を備える。即ち、 予め登録されているシステム辞書に基づいて分野毎の小 型辞書を作成する情報処理のプログラムコードが格納さ れたコンピュータ可読メモリであって、前記小型辞書を 構成する単語数を指定する指定工程のプログラムコード 30 と、前記小型辞書を構成する単語を決定するための学習 用文書データと、大量文章データに基づいて、該小型辞 書を構成する構成工程のプログラムコードと、前記小型 辞書を評価するための評価用文章データに対し、前記シ ステム辞書を用いてアクセント処理を行ない、第1アク セント句情報を出力する第1アクセント処理工程のプロ グラムコードと、前記評価用文章データに対し、前記小 型辞書を用いてアクセント処理を行い、第2アクセント 句情報を出力する第2アクセント処理工程のプログラム コードと、前記第2アクセント句情報の前記第1アクセ 40 ント句情報に対する相対精度を算出する算出工程のプロ グラムコードと、前記相対精度と前記小型辞書を対応づ けて記憶媒体に管理する管理工程とを備える。

[0021]

【発明の実施の形態】以下、図面を参照して本発明の好 適な実施形態を詳細に説明する。

【0022】図1は本実施形態の情報処理装置の構成を 示すプロック図である。

【0023】図1において、CPU1101はメインパス1106を介して情報処理装置1000全体の制御を 50

実行するとともに、情報処理装置1000の外部に接続 される入力装置1110(例えば、マイク、イメージス キャナ、記憶装置、ネットワーク回線を介して接続され る他の情報処理装置、電話回線を介して接続されるファ クシミリ等)を入力 I / F (インタフェース) 1104 を介して制御する。また、情報処理装置1000の外部 に接続される出力装置1111(例えば、スピーカ、プ リンタ、モニタ、ネットワーク回線を介して接続される 他の情報処理装置、電話回線を介して接続されるファク シミリ等)を出力 I / F 1 1 0 5 を介して制御する。ま た、CPU1101は、KBDI/F(キーボードイン タフェース)1107を介して入力部(例えば、キーボ ード1112やポインティングデバイス1113やペン 1114)から入力された指示に従って、音声の入力、 音声認識処理、音声合成処理、等の一連の処理を実行す る。更に、入力装置1110より入力された音声データ や、キーボード1112やポインティングデバイス11 13やペン1114を用いて作成されたデータを表示す る表示部1109をビデオI/F(インタフェース)1 108を介して制御する。

【0024】ROM1102は、CPU1101の各種制御を実行する各種制御プログラムを記憶している。RAM1103は、CPU1101によりOSや本発明を実現するための制御プログラムを含むその他の制御プログラムがロードされ実行される。また、制御プログラムを実行するために用いられる各種作業領域、一時待避領域として機能する。また、入力装置1110より入力された画像データや、キーボード1112やポインティングデバイス1113やペン1114を用いて作成された画像データを、一旦、保持するVRAM(不図示)が構成されている。

【0025】次に、本実施形態の情報処理装置の機能構成について、図2を用いて説明する。

[0026] 図2は本実施形態の情報処理装置の機能構成を示すプロック図である。

【0027】101は、本装置を動作させるための初期設定値を保持する初期設定保持部である。初期設定値は、作成対象の小型辞書112の登録語数とその中で学習用文書データ110に出現する単語の中から選択する単語数の組である。この組を複数設定することもできる。

【0028】102は、入力文章データ(テキストデータ)に対し形態素解析を行う形態素解析部である。103は、入力文章データに対しアクセント処理を行ないアクセント句情報を出力するアクセント処理部である。アクセント句情報は、読み、アクセント句の区切り、アクセント型からなる。104は、大量文章データ108に含まれる単語の頻度情報を保持する大量文章単語頻度情報保持部である。

【0029】105は、学習用文章データ109に含ま

40

れる単語の頻度情報を保持する学習用文章単語頻度情報 保持部である。106は、アクセント句の相対精度を評価するアクセント句相対精度評価部である。ここで、アクセント句の相対精度とはシステム辞書111で解析したアクセント句を正解とみなした場合に、そのアクセント句と小型辞書112で解析したアクセント句が一致する度合(精度)を示す値のことである。

【0030】107は、本装置が作成した小型辞書112とアクセント句相対精度の組を保持する小型辞書保持部である。108は、雑誌、新聞等の大量文章データである。109は、複数種類の適用分野の文章データに対し、各適用分野毎の小型辞書112を構成する単語を決定するための)学習用に割り当てた学習用文章データである。110は、複数種類の適用分野の文章データに対し、各適用分野毎の小型辞書112の評価用に割り当てた評価用文章データである。111は、本装置が持つすべての単語を含んだシステム辞書である。112は、後述する処理によって本装置が作成した適用分野毎の小型辞書である。

【0031】尚、大量文章単語頻度情報保持部104、 学習用文章単語頻度情報保持部105、アクセント句相 対精度評価部106、小型辞書保持部107、大量文章 データ108、学習用文章データ109、評価用文章デ ータ110、システム辞書111、小型辞書112は、 例えば、ROM1102、RAM1103、あるいは記 憶装置として用いられる入力装置1110上で実現される。

【0032】次に、本実施形態の情報処理装置で実行される処理について、図3を用いて説明する。

【0033】図3は本実施形態の情報処理装置の処理手順を示すフローチャートである。

[0034]まず、ステップS201で、作成対象の小型辞書112の登録語数とその中で学習用文章データ109に出現する単語の中から選ぶ単語数との組を設定する。例えば、(30000,20000)は、登録語数が30000語であり、学習用文章データ109から選ぶ単語が20000語の辞書を作成することを設定する。残りの10000語は、大量文章データ108に出現する単語の中から選ぶ。また、この組を複数個設定してもよい。

【0035】次に、ステップS202で、大量文章データ108に対しシステム辞書111を用いて形態素解析を行う。ステップS203で、ステップS202の形態素解析結果を用いて、大量文章データ108に出現する単語の頻度を計算し、頻度の高い順に大量文章単語頻度情報保持部104に保持する。ここで、大量文章単語頻度情報保持部104が保持するデータ構成例を、図4に示す。図4に示すように、大量文書単語頻度情報保持部104では、品詞別に、その品詞の見出しとその見出しの出現頻度を対応付けて管理している。

【0036】次に、ステップS204で、学習用文章データ109に対しシステム辞書111を用いて形態素解析を行う。ステップS205で、ステップS204の形態素解析結果を用いて学習用文章データ109に出現する単語の頻度を計算し、頻度の高い順に学習用単語頻度情報保持部105に保持する。ここで、学習用単語頻度情報保持部105が保持するデータ構成例を、図5に示す。図5に示すように、学習用単語頻度情報保持部105では、大量文書単語頻度情報保持部104と同様に、品詞別に、その品詞の見出しとその見出しの出現頻度を対応付けて管理している。

【0037】次に、ステップS206で、評価用文章データ110に対しシステム辞書111を用いてアクセント処理を行う。この処理結果は、アクセント句相対精度評価部106に保持する。ここで、アクセント句相対精度評価部106が保持するデータ構成例を、図6に示す。図6は、評価用文書データ110として、「半導体メモリを搭載したメモリを販売する」、「パソコンで生成したデータを再生する」、「単四型電池を使用する」に対し、システム辞書111を用いてアクセント処理を行った場合の処理結果を示している。処理結果は、評価用文書データの読みと、アクセント句の切れ目と、アクセント型からなり、図6では、読みを「カタカナ」、アクセント句の切れ目を「/」、アクセント列を「↓」で表している。

【0038】次に、ステップS207で、ステップS2 01で設定した小型辞書112に登録する単語数とその 中で学習用文章データ109に出現する単語の中から選 ぶ単語数の組が残っているか否かを判定する。単語数の 組が残っていない場合(ステップS207でNO)、処 理を終了する。一方、単語数の組が残っている場合(ス テップS207でYES)、ステップS208に進む。 【0039】次に、ステップS208で、単語数の組を 一つ取り出す。例として、単語数の組(30000,2 0000)を取り出した場合、学習用文章単語頻度情報 保持部105に保持されている単語の中から頻度が高い もの上位20000語を取り出し、小型辞書112に登 録する。次に、大量文章単語頻度情報保持部104に保 持されている単語の中で頻度の高いものから小型辞書1 12に登録する。登録対象の単語がすでに登録されてい る場合は、次の単語へ移る。そして、小型辞書112の 登録語数が3000節になるまで続ける。

50 る」、「パソコンで生成したデータを再生する」、「単

9

四型電池を使用する」に対し、小型辞書112を用いて アクセント処理を行った場合の処理結果を示している。 図7では、評価用文書データ110の内、「半導体メモ リを搭載したメモリを販売する」のアクセント処理結果 が、図6の場合と異なっていることがわかる。これは、 小型辞書112に「半導体」という単語が登録されてお らず、「半導体」を「半導」と「体」の2文字として認 識されてしまった結果、その読みとして「ハンドウ」と 「カラダ」が生成されていることがわかる。

【0041】次に、ステップS209で、システム辞書 10 111を用いたアクセント処理(ステップS206)の 処理結果(図6)と小型辞書112を用いたアクセント 処理(ステップS208)の処理結果(図7)を用い て、アクセント句相対精度を計算する。アクセント句相 対精度の値は、次式を用いて計算する。つまり、アクセ ント句相対精度= (切れ目とアクセント型が一致したア クセント句数) ÷ (システム辞書111を用いたアクセ ント処理の処理結果によるアクセント句数)。

【0042】尚、切れ目とアクセント型が一致するアク セント句はDPマッチング等の手法を用いることで計算 20 可能である。図8に一致するアクセント句の例を示す。 図中、実線で囲まれた部分がシステム辞書111でアク セント処理した処理結果のアクセント句、破線で囲まれ た部分が小型辞書112でアクセント処理した処理結果 のアクセント句を示す。この図8の場合のアクセント句 相対精度は、7÷10=0.7となる。

【0043】次に、ステップS210で、ステップS2 07で選択した小型辞書112とステップS209で計 算したアクセント句相対精度の値を小型辞書保持部10 7に保持する。

【0044】以上の処理を繰り返すことにより、小型辞 書保持部107に小型辞書112が複数個生成され、各 小型辞書112には、それぞれのアクセント句相対精度 が保持される。そして、このアクセント句相対精度によ り、各小型辞書112の性能を図ることができる。つま り、アクセント句相対精度に基づいて、ステップS20 1 で設定する組を任意に変更することで、よりアクセン ト句相対精度の高い組の小型辞書112を構成すること ができる。

【0045】以上説明したように、本実施形態によれ ば、新聞等の大量文章と適用分野の少量文章から、大規 模なシステム辞書のサブセットとしての小型辞書を適用 分野に適した形で作成することができる。また、アクセ ント句相対精度を評価基準としているため、辞書を利用 するシステムのアルゴリズム(統計的手法、ルールベー スなど)に依存しない。

【0046】尚、本発明は、複数の機器(例えば、ホス トコンピュータ、インタフェース機器、リーダ、プリン タなど) から構成されるシステムに適用しても、一つの 機器からなる装置(例えば、複写機、ファクシミリ装置 50 一夕構成例を示す図である。

など) に適用してもよい。

【0047】また、本発明の目的は、前述した実施形態 の機能を実現するソフトウェアのプログラムコードを記 録した記憶媒体を、システムあるいは装置に供給し、そ のシステムあるいは装置のコンピュータ(またはCPU やMPU) が記憶媒体に格納されたプログラムコードを 読出し実行することによっても、達成されることは言う までもない。

【0048】この場合、記憶媒体から読出されたプログ ラムコード自体が前述した実施形態の機能を実現するこ とになり、そのプログラムコードを記憶した記憶媒体は 本発明を構成することになる。

【0049】プログラムコードを供給するための記憶媒 体としては、例えば、フロッピディスク、ハードディス ク、光ディスク、光磁気ディスク、CD-ROM、CD -R、磁気テープ、不揮発性のメモリカード、ROMな どを用いることができる。

【0050】また、コンピュータが読出したプログラム コードを実行することにより、前述した実施形態の機能 が実現されるだけでなく、そのプログラムコードの指示 に基づき、コンピュータ上で稼働しているOS(オペレ ーティングシステム)などが実際の処理の一部または全 部を行い、その処理によって前述した実施形態の機能が 実現される場合も含まれることは言うまでもない。

【0051】更に、記憶媒体から読出されたプログラム コードが、コンピュータに挿入された機能拡張ボードや コンピュータに接続された機能拡張ユニットに備わるメ モリに書込まれた後、そのプログラムコードの指示に基 づき、その機能拡張ボードや機能拡張ユニットに備わる 30 CPUなどが実際の処理の一部または全部を行い、その 処理によって前述した実施形態の機能が実現される場合 も含まれることは言うまでもない。

【0052】本発明を上記記憶媒体に適用する場合、そ の記憶媒体には、先に説明した図3に示すフローチャー トに対応するプログラムコードが格納されることにな る。

[0053]

【発明の効果】以上説明したように、本発明によれば、 汎用性が高く、かつ精度の良い音声合成用辞書を作成す ることができる情報処理装置及びその方法、コンピュー 夕可読メモリを提供できる。

【図面の簡単な説明】

【図1】本実施形態の情報処理装置の構成を示すプロッ ク図である。

【図2】本実施形態の情報処理装置の機能構成を示すブ ロック図である。

【図3】本実施形態の情報処理装置の処理手順を示すフ ローチャートである。

【図4】本実施形態の大量文章単語頻度情報保持部のデ

【図5】本実施形態の学習用単語頻度情報保持部のデータ構成例を示す図である。

【図6】本実施形態の評価用文章データに対しシステム辞書を用いてアクセント処理を行った場合の処理結果を示す図である。

【図7】本実施形態の評価用文章データに対し小型辞書を用いてアクセント処理を行った場合の処理結果を示す図である。

【図8】本実施形態のアクセント句相対精度の計算方法 を説明するための図である。


【符号の説明】

101 初期設定保持部


- 102 形態素解析部
- 103 アクセント処理部
- 104 大量文章単語頻度情報保持部
- 105 学習用文章単語頻度情報保持部
- 106 アクセント句相対精度評価部
- 107 小型辞書保持部
- 108 大量文章データ
- 109 学習用文章データ
- 110 評価用文章データ
- 10 111 システム辞書
 - 112 小型辞書


【図1】

[図3]



[図2]





[図5]

品詞	見出し	類皮
格勒詞	n	22190
格助男	ŧ	18657
サ安名阿	サービス	2002
名詞	パソコン	1729


【図4】

[図6]


ハンドウタイメ↓モリオ/トウサイシタ/メ↓モリラ/ハンパイスル
パソコンデノセイセイシタノデーータオノサイセイスル
タンコンガタデ↓ンチオ/ショウスル

品舞	見出し	根皮
格助詞	n	8389136
格助剤	ŧ	5278827
沒有名詞	. 日本	305089
助数割	PI	304169
		·

[図8]



【図7】



This Page is Inserted by IFW Indexing and Scanning Operations and is not part of the Official Record

BEST AVAILABLE IMAGES

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images include but are not limited to the items checked:

BLACK BORDERS

IMAGE CUT OFF AT TOP, BOTTOM OR SIDES

FADED TEXT OR DRAWING

BLURRED OR ILLEGIBLE TEXT OR DRAWING

SKEWED/SLANTED IMAGES

COLOR OR BLACK AND WHITE PHOTOGRAPHS

GRAY SCALE DOCUMENTS

LINES OR MARKS ON ORIGINAL DOCUMENT

REFERENCE(S) OR EXHIBIT(S) SUBMITTED ARE POOR QUALITY

IMAGES ARE BEST AVAILABLE COPY.

OTHER:

As rescanning these documents will not correct the image problems checked, please do not report these problems to the IFW Image Problem Mailbox.

